

SVEUČILIŠTE U ZAGREBU
FILOZOFSKI FAKULTET
ODSJEK ZA INFORMACIJSKE I KOMUNIKACIJSKE ZNANOSTI
AKADEMSKA GODINA 2016./2017.

Daria Mrkus

Korisnički pristup sadržajnoj obradi na primjeru stranica za društveno čitanje

Diplomski rad

Studij: Izvanredni diplomski studij bibliotekarstva

Mentorica: dr. sc. Sonja Špiranec, izv. prof.

Zagreb, lipanj 2017.

SADRŽAJ

Sažetak.....	2
1. Uvod.....	3
2. Korisnički pristup sadržajnoj obradi.....	5
2.1 Korisnik u ulozi indeksera.....	5
2.2 Korisničko označivanje i folksonomije.....	7
2.3 Recenziranje i ocjenjivanje.....	15
3. Stranice za društveno čitanje.....	17
3.1 Suradnički informacijski sustavi.....	17
3.2 Nova paradigma čitanja.....	19
3.3 Pregled i karakteristike stranica za društveno čitanje.....	21
4. Istraživanje: korisničke oznake na stranicama za društveno čitanje.....	29
5. Zaključak.....	35
6. Bibliografija.....	37

Sažetak

Posljednjih desetak godina, zahvaljujući ponajprije inovacijama vezanima uz Web 2.0 okruženje, svjedočimo proliferaciji raznolikih suradničkih informacijskih sustava koji „(...)uglavnom služe upravljanju osobnim izvorima, ali također omogućuju suradničko stvaranje javne baze podataka dostupne svim (ako je potrebno, registriranim) korisnicima. Nadalje, izvore na suradničkim informacijskim sustavima indeksiraju korisnici, odnosno, izvori su predstavljeni na korisničkoj platformi putem korisničkih oznaka (*tagova*)“ (Peters, 2009: 19-20). Folksonomije, kao rezultat korisničkog neformalnog označivanja odozdo putem slobodno odabranih oznaka, smatraju se stoga važnim elementom suradničkih informacijskih sustava. Ovisno o vrsti sustava, kao i o tipu izvora koji su u njemu zastupljeni, korisnicima je omogućen i ponešto drugačiji pristup sadržajnoj obradi izvora poput recenziranja ili ocjenjivanja. Mrežne stranice za društveno čitanje (*social reading sites*, *bookshelf sites*, *social cataloguing sites*) kao što su Goodreads, LibraryThing, Libib, Anobii, Bookstr i druge primjer su suradničkih informacijskih sustava na kojima se korisnici okupljaju u zajednice na temelju dijeljenog interesa te na kojima se nova paradigma društvenog čitanja pokazuje komplementarnom s novom paradigmom subjektivnog označivanja dokumenata. Time one jasno demonstriraju kako korisničke intervencije mogu poslužiti kao više ili manje efikasno sredstvo za organizaciju i reprezentaciju znanja, za pronalaženje informacija te na koji način mogu utjecati na socijalni aspekt platformi u pitanju. Međutim, razmatranje korisničkih oznaka, potom i ocjena te recenzija (kvantitativnih informacija o stavovima korisnika o dokumentu te elaboriranih pojedinačnih predočavanja sadržaja kroz subjektivnu prizmu mišljenja) uz lingvističku i funkcionalnu analizu oznaka na spomenutim stranicama za društveno čitanje potvrdit će postojanje problema na koji većina proučavatelja folksonomija redovito ukazuje: korisnička obrada sadržaja odozdo koja počiva na principima kao što su otvorenost, personalnost, subjektivnost, demokratičnost i slobodan izbor ipak zahtijeva izvjestan stupanj normalizacije ili kontrole kako bi se optimizirale neke od ključnih funkcionalnosti suradničkih servisa: predstavljanje znanja, pretraživanje i pronalaženje informacija te realizirana društvena dimenzija.

Ključne riječi: korisnička obrada, korisničko označivanje, folksonomije, recenziranje, ocjenjivanje, suradnički informacijski sustavi, stranice za društveno čitanje

1. UVOD

Sadržajno označivanje koje možemo definirati kao „(...) čin utvrđivanja sadržajne građe dokumenta i iskazivanje sadržaja u odabranom jeziku za označivanje“ (Špiranec, 2014: 3) oduvijek je predstavljalo svojevrsan izazov za teoriju i praksu informacijskih znanosti. Bilo da se radi o označivanju dokumenata kako bi se adekvatno predstavili informacijski sadržaji te time omogućilo njihovo pretraživanje i pronalaženje u sklopu tradicionalnih informacijskih (AKM) ustanova, bilo da se radi o pokušajima da se primjereno obradi bujica informacija na internetu, sadržajno označivanje suočava se s fundamentalnim problemom: sadržajna obrada, kao i formalni opis, načelno teži zadovoljavanju kriterija objektivnosti i nepristranosti, međutim, za razliku od potonjeg čini se da oni za nju vrijede samo kao regulativna ideja te se subjektivnost kontinuirano pokazuje implicitnim sastavnim dijelom sadržajne obrade. Koraci koji se moraju poduzeti pri označivanju – obično se govori o analizi dokumenta te o prijevodu utvrđenog sadržaja u odabrani jezik za predmetno označivanje – uvijek u sebi sadrže element tumačenja od strane osobe koja indeksira, što bi se moglo izbjeći tek u slučaju da je proces označivanja u potpunosti automatiziran. Budući da se pokazalo da niti automatsko označivanje nije idealan način sadržajnog označivanja i da još uvijek nema boljeg rješenja od barem djelomičnog uključivanja ljudskog intelekta, zaključak koji se nameće jest da su subjektivnost i pristranost imanentni indeksiranju, drugim riječima: „Za sadržajno označivanje, naime, nije dovoljno odrediti predstavljanje sadržaja dokumenta u odabranom indeksnom jeziku, nego predstavljanje interpretacije sadržaja dokumenta. Interpretacije su pak, po svojoj prirodi iznimno subjektivni postupci, što je u raskoraku sa samom svrhom indeksiranja, koje bi trebalo biti objektivno, neutralno i dosljedno“ (Ibid.: 3-4). Dok se s jedne strane pokušavalo što više smanjiti udio neobjektivnosti u indeksiranju, s druge se strane, zahvaljujući prvenstveno softverskim novinama koje su drastično izmijenile krajolik *weba*, pojavila upravo suprotna tendencija *laissez-faire* sadržajnog opisa, principijelno subjektivnog, personalnog, nekontroliranog i pristranog kojim se znanje organizira, predstavlja i kojim se omogućuje njegova pretraživost. Taj obuhvatni i rastući fenomen možemo nazvati korisničkom sadržajnom obradom, a osim svog najprominentnijeg vida u obliku korisničkog označivanja (*tagging*), uključivala bi sad već uvriježene prakse korisničkog ponašanja u Web 2.0 okruženju kao što su recenziranje i ocjenjivanje.

Punopravno uključivanje korisnika u djelatnost označivanja sadržaja koje je donedavno bilo isključiva povlastica informacijskih stručnjaka doista ne bi bilo moguće bez tehnoloških uvjeta koji danas omogućavaju pristup internetu za sve veći broj korisnika, niti bez softverskih inovacija koje su stvorile Web 2.0 okruženje, verziju mreže čiji je temelj korisnička prisutnost, uključenost i suradnja. Posebno je u tom smislu značajan prirast raznovrsnih suradničkih informacijskih sustava koji su otvorili vrata ne samo korisničkom stvaranju, već i drugačijoj obradi i prezentaciji informacija na *webu*. Upravo se u kontekstu suradničkih informacijskih sustava prije nepunih petnaest godina pojavila praksa označivanja odozdo prilikom kojeg korisnici po vlastitom nahođenju dodjeljuju označitelje dokumentima: „Korisnik nije vezan nikakvim smjernicama. Taj proces slobodnog označivanja zove se korisničko označivanje (tagiranje)“ (Peters, 2009: 153). Drugačije mogućnosti korisničke obrade koje po samoj svojoj naravi uključuju još više slobode i subjektivnosti te predstavljanje sadržaja kroz filter mišljenja i stavova kao što su recenziranje i ocjenjivanje pokazale su se privlačnima posebno u nekim vrstama suradničkih sustava kao što su takozvane stranice za društveno čitanje - stranice koje su zbog svoje uske veze s korisničkim pristupom sadržajnoj obradi predmet ovoga rada. Rastuća popularnost mrežnih mjesta te vrste kao što su primjerice Goodreads, LibraryThing, Anobii i druge za mnoge je proučavatelje postala ozbiljno svjedočanstvo o kulturnom zaokretu u kojem i korisnička obrada dokumenata – u ovom slučaju knjiga – funkcionira kao integralni dio nove paradigme čitanja: čitanje ne više kao izolirana i samotnička aktivnost, već čitanje kao društveni čin, dijeljenje i suradnja.

Do sada je s korisničke strane na stranicama za društveno čitanje obrađena iznimno velika količina dokumenata, a sama je praksa pokazala određene kvalitete zbog koje su se mnoga istraživanja (usp. Špiranec i Livaja (2014), Špiranec i Ivanjko (2013); Thomas, Caudle i Schmitz, (2009), Voorbij (2012), Bates i Rowley (2011), Yi i Chan, (2009)) usmjerila na proučavanje potencijalnih koristi za AKM ustanove te načina na koji implementacija korisničkog označivanja, ocjenjivanja i recenziranja može unaprijediti označivanje i pretraživanje informacija uopće, a posebice u slučaju knjižničnih mrežnih kataloga od kojih su pojedini integrirali neke od navedenih mogućnosti, primjerice katalog Knjižnice Filozofskog fakulteta u Zagrebu koji dopušta korisničko označivanje. Međutim, druga skupina istraživanja (usp. Weaver (2007), Thomas, Caudle i Schmitz (2010), Naik (2012)) pokazala je kako korisnička obrada manifestira mnoge nedostatke koje bi bilo potrebno minimizirati oslanjajući se pretežno na tradicionalne

modele kontrole jezika za sadržajnu obradu. Istraživanje provedeno u sklopu ovoga rada koje se bazira na lingvističkoj i funkcionalnoj analizi oznaka što su korisnici dodijelili dokumentima predstavljenima na najpopularnijim stranicama za društveno čitanje također polazi od pretpostavke da postoji visok stupanj subjektivnosti i personalnosti u korisničkom označivanju, iz čega bi slijedilo da unatoč evidentnim prednostima korisničke obrade sadržaja odozdo koja počiva na principima kao što su otvorenost, demokratičnost i slobodan izbor ona ipak zahtijeva izvjestan stupanj normalizacije ili kontrole kako bi se optimiziralo predstavljanje znanja, pretraživanje i pronalaženje informacija, te omogućila i očuvala društvena dimenzija svojstvena stranicama za društveno čitanje.

2. KORISNIČKI PRISTUP SADRŽAJNOJ OBRADI

2.1. Korisnik u ulozi indeksera

Sadržajna obrada u svom institucionaliziranom obliku uvriježeno se koristi nekom vrstom predmetnog jezika za obradu dokumenata. Za razne varijante predmetnih jezika vrijedi da one neminovno predstavljaju određeni odmak od prirodnih jezika: „Predmetni su jezici umjetni jezici, izrađeni za posebnu svrhu pronalaženja informacija. Kao takvi, razlikuju se u određenom bitnom pogledu od prirodnih jezika. Kako je to Wittgenstein formulirao, dva jezika predstavljaju dvije različite jezične igre koje se igraju s različitim novčićima prema različitim pravilima. Razlike se mogu prikazati suprotstavljanjem predmetnih i prirodnih jezika s obzirom na njihov rječnik, semantiku i sintaksu“ (Svenonius, 2005: 126). U pogledu rječnika predmetnoga jezika, odnosno vokabulara koji se sastoji od termina predviđenih za označivanje, uvijek je potrebno donijeti određene odluke prva od kojih je principijelna: koje kriterije je potrebno zadovoljiti kako bi određeni naziv ušao u predmetni jezik. Kriteriji koji su se u tom smislu profilirali su jamstvo predložka, koje „(...) nalaže da se rječnik predmetnog jezika empirijski izvodi iz literature koju namjerava opisati“ (Ibid.: 132), jamstvo uporabe, koje zahtijeva da rječnik predmetnog jezika odgovara jeziku domene korisnika koji će dokumente pretraživati te strukturno jamstvo koje propušta nazive koji podržavaju arhitekturu predmetnog jezika, odnosno koji mogu pospješiti pronalaženje informacija ili okupljanje termina, iako sami nisu nužno elementi uvriježenog vokabulara predložaka, niti ih korisnici uobičajeno upotrebljavaju kad formuliraju svoje

informacijske upite. Slijedom brojnih rasprava o tome do koje mjere treba inzistirati na kojem kriteriju, drugim riječima koliko je opravdano uvoditi nazive svojstvene korisničkim upitima nauštrb nazivima ekstrahiranim iz dokumenata ili obratno, pokazalo se da jamstvo predloška samo po sebi nije dovoljno i da je jamstvo uporabe itekako važno te bi korisnik kao pretpostavljena figura koja traži informaciju trebao biti neprestano u vidu u cijelom procesu sadržajnog označivanja: „I u tom je pogledu, a to je moguće tvrditi za cjelokupno informacijsko područje, usluge i poslanje informacijskih ustanova, korisnik mjera svih stvari. Jedan je od ključnih aspekata pri izgradnji predmetnoga jezika i izbora nazivlja koji ga čini korisničko jamstvo, koje osigurava da se rječnik korisnika zrcali u predmetnom jeziku. Unatoč snažnom teorijskom utemeljenju korisničko se jamstvo u praksi često ostvaruje nasumce i *ad hoc* zbog poteškoća u sustavnom utvrđivanju korisničkoga rječnika“ (Špiranec i Ivanjko, 2012: 58-59). Svakako, informacijskom stručnjaku koji indeksira dokument iz profesionalne perspektive ili autoru koji ključnim riječima označava vlastiti tekst teško je pretpostaviti koje će nazive upotrijebiti korisnik i kako će formulirati svoj informacijski upit. Jamstvo uporabe ili korisničko jamstvo utoliko je moglo u punom smislu postati operativno tek kad su se stvarni korisnici uključili u proces sadržajne obrade, što je omogućeno početkom ovog tisućljeća zahvaljujući tehnologijama Weba 2.0. Suradničko mrežno okruženje omogućilo je korisniku ne samo da objavljuje i dijeli vlastite sadržaje, već i da ih organizira i označuje te tako omogući njihovu pretraživost. Jedna od ključnih aktivnosti koje su korisniku pritom stavljene na raspolaganje je *tagiranje*, praksa dodjeljivanja korisničkih oznaka. Utoliko je nedostavno reći da se zahvaljujući novim modelima organizacije i predstavljanja informacija na internetu koji se otvaraju prema korisnicima (posebice u sklopu suradničkog *weba*) dodatni naglasak stavlja na korisničko jamstvo. Naime, načinjen je još jedan korak dalje: ne samo da jezik za indeksiranje odražava pretpostavljeni vokabular korisnika pri pretraživanju, već se on izgrađuje na temelju stvarnog korisničkog vokabulara - jer upravo korisnik označava bez restrikcija, normalizacije ili kontrole birajući riječi iz prirodnog jezika koje on/a smatra adekvatnim za predstavljanje informacijskog sadržaja u pitanju, a rezultat takvog označivanja i označivanja drugih korisnika stvara rezultat odozdo – u obliku takozvanih folksonomija. Doista se može reći da se radi o promjeni paradigme u označivanju: „Iako su subjektivne oznake i korisničko označivanje općenito smješteni u subjektivni dio kontinuuma različitih pristupa označivanju, treba ga jasno razlikovati od ranije definiranog pristupa usmjerenog na korisnike ili zahtjeve. Taj pristup, naime, izravno temelji

analizu dokumenta na analizi i razumijevanju domene i korisnika domene. (...) Svakako je riječ o subjektivnom pristupu označivanju jer umnožava informacijske mogućnosti dokumenta i omogućuje različite perspektive i gledišta (ovisno o domeni), ali ta subjektivnost nema individualno obilježje kao korisničko označivanje. Korisničko označivanje, prema tom tumačenju, krajnji je vid potpunog subjektivnog označivanja, gdje se moguća informacijska značenja ne ravnaju prema domeni i ne definiraju iz perspektive stručnjaka koji označuje, nego je moguć gotovo beskonačan broj različitih tumačenja, koliko ima korisnika koji označuju“ (Špiranec, 2014: 11).

Danas je moguće da u određenim suradničkim sustavima svaki korisnik bude indeksir, da sadržajno obradi dokument dostupan na internetu te da ga tako organiziranog i reprezentiranog ponudi drugim korisnicima. Sloboda, otvorenost, nepostojanje kontrole nad prirodnim jezikom kojim korisnici označuju izvore, a koji rezultiraju u dinamičnom, multiperspektivnom i višeglasnom predstavljanju informacija, na različite se načine očituju u tri najučestalije prakse korisničke sadržajne obrade na suvremenom *webu*: korisničkom označivanju, recenziranju i ocjenjivanju.

2.2. Korisničko označivanje i folksonomije

U podnaslovu knjige *Tagging*, jedne od prvih monografija posvećenih korisničkom označivanju iz 2008. godine, autor Gene Smith ukratko sažima značenje korisničkih oznaka. Za Smitha one su „korisnički generirani metapodaci za društveni Web“¹(Smith, 2008), dok ih Isabella Peters živopisno karakterizira kao „elektronički ekvivalent *post-it* bilježaka“ (Peters, 2009: 153). Doista, proces korisničkog označivanja nalikuje praksi neobaveznog priljepljivanja etiketa nekom sadržaju, bez ikakvih restrikcija, uputstava ili smjernica. Budući da se označivanje u najvećem broju slučajeva odvija na javno dostupnim mrežnim mjestima koja su otvorena za korisničku participaciju, uglavnom u kontekstu takozvanih suradničkih informacijskih sustava², drugi korisnici prema vlastitom nahođenju dodjeljuju već postojeće ili sasvim nove oznake pa

¹ Ukoliko nije drugačije naznačeno, svi prijevodi s engleskoga jezika su moji.

² Postoje i slučajevi druge vrste prilikom kojih *tagovi* služe isključivo korisniku za organizaciju i označivanje vlastitih informacija, kao pri označivanju dokumenata u Microsoft Windows datotekama ili označivanju osobne elektroničke pošte koje omogućuje Gmail servis. Ukupnost takvih korisničkih oznaka jednog korisnika ponekad se naziva personomijom (Usp. Peters, 2009: 156).

označivanje raste neplanskom suradnjom. Rezultat korisničkog označivanja naziva se folksonomija: „Folksonomija je rezultat osobnog i slobodnog korisničkog označivanja informacija i objekata (bilo čega što posjeduje URL) za vlastito pretraživanje. Označivanje se odvija u društvenom okruženju, obično dijeljenom i otvorenom za druge. Folksonomija se stvara iz čina označivanja koje provodi osoba koja konzumira informaciju“ (Vander Wal, 2007). Upravo je Thomas Vander Wal 2004. godine skovao termin, spojivši riječi *folk* i *taksonomy* kako bi naglasio da se radi o taksonomiji koju su stvorili korisnici. Unatoč prijedorima oko prikladnosti te novokovanice, a koji su proizašli iz činjenice da se ovdje u pravom smislu ne radi o vrsti taksonomije od kojih se folksonomije fundamentalno razlikuju u tome što se ne izgrađuju na temelju uspostavljenih hijerarhijskih odnosa i utvrđene relacijske semantike, naziv se uvriježio te se i dalje upotrebljava za sve učestaliji fenomen čija se prva značajna pojava na internetu detektira godinu dana ranije od pojave samog pojma. Te je 2003. godine na Del.icio.us, mrežnu stranicu za društveni *bookmarking*, po prvi put uvedena mogućnost brzog spremanja zanimljivih poveznica uz korisničko označivanje te pretraživanja preko istih oznaka ili preko hiperveza koje vode na korisničke profile, čime se omogućilo i stvaranje rudimentarne *on-line* zajednice (usp. Smith, 2008: 161). Korisničko označivanje ubrzo se počelo koristiti na Flickru, platformi za dijeljenje fotografskih sadržaja, a potom su ga počeli uvoditi sve brojniji i raznolikiji suradnički sistemi i mrežna mjesta, uključujući stranice za objavljivanje i dijeljenje multimedije (Last.fm, Youtube), stranice za društveni *bookmarking*, mrežna mjesta za e-trgovinu poput Amazona, stranice za društveno čitanje kao što su Goodreads ili Library Thing, kao i aplikacije i programi za upravljanje osobnim informacijama (*personal information management*). Različiti informacijski sustavi ponudili su unekoliko drugačije mogućnosti označivanja za svoje korisnike pa su se do danas profilirale dvije osnovne vrste folksonomija s obzirom na osobu ili osobe koje su angažirane u dodjeljivanju oznaka - široke i uske folksonomije, odnosno: „1) folksonomije koje dopuštaju višestruko dodjeljivanje korisničkih oznaka istom izvoru te 2) folksonomije koje se generiraju isključivo od autorovih oznaka, a koji može dopustiti dodavanje novih oznaka drugim korisnicima“ (Peters, 2008: 164). U potonjem slučaju govori se i o proširenim uskim folksonomijama (usp. Ibid.: 166).

Širenje korisničkog označivanja u navedenim varijantama tijekom nepunih petnaest godina od inauguriranja na *webu* svjedoči o njegovim brojnim prepoznatim i iskorištenim prednostima. Međutim, valja naglasiti da je posebno zanimljivu ulogu odigrala upravo

moгуćnost stvaranja širokih folksonomija na različitim suradničkim sustavima u kojima svoj udio u indeksiranju daju svi zainteresirani korisnici, sudjelujući tako u praksi suradničkog označivanja, o kojoj će još biti riječi.

Sustav na kojem se temelji korisničko označivanje uvijek sadrži tri elementa, odnosno, neizostavno se radi o tripartitnoj strukturi koju sačinjavaju korisnik, korisnička oznaka (*tag*) i izvor koji se označuje. Drugim riječima: „Korisničko označivanje može se raščlaniti na prilično jednostavan model u kojem korisnici dodjeljuju oznake izvorima kao što su fotografije ili mrežne stranice unutar sistema“ (Smith, 2008: 4). Relacije koje se na taj način uspostavljaju tvore u konačnici složenu mrežu mogućih navigacija, primjerice, zainteresirani korisnik se može kretati slijedeći oznake kao poveznice koje ga dovode do označenih izvora i do korisnika koji su ih iskoristili da označe izvor. Svaka od navedenih instancija može funkcionirati kao hiperveza koja vodi do drugih elemenata u sistemu koji predstavljaju nove hiperveze i tako dalje. U takvom sistemu korisničke oznake omogućavaju da se znanje prezentira, da informacije budu pretražive te da se uspostave uvjeti za društvenu interakciju korisnika u *on-line* okruženju.

Gore navedene mogućnosti kretanja unutar sustava korisničkog označivanja vode do važne posljedice koja se tiče pretraživanja, a to je da je za pronalazak korisnički označenih informacija prikladnije pregledavanje³ nego ciljano pretraživanje: „Kapacitet folksonomija da jače podržavaju pregledavanje (*browsing*) preko informacijske platforme nego specifične pretrage formulirane u obliku upita ili pomoću polja za pretraživanje često se smatra jednom od njihovih većih prednosti. Učinkovit i praktičan alat za pregledavanje ipak zahtijeva da se zadovolje kriteriji dizajna drugačiji no što je to slučaj s jednostavnim instrumentima za pretraživanje“ (Peters, 2009: 314). Tom tipu dinamike traženja informacija nesumnjivo doprinosi način vizualizacije oznaka koji se profilirao kao uvriježen - tzv. oblak korisničkih oznaka (*tag cloud*). Dok se u nešto manje atraktivnom modelu predočavanja kakav predstavljaju liste korisničkih oznaka (*tag lists*) one redaju u obliku klasičnih popisa prema kriteriju učestalosti ili abecednim slijedom, u oblacima su oznake obično poredane alfabetski, međutim koriste se različite veličine i/ili boje slova za isticanje pojedinih oznaka kako bi se ukazalo na veću

³ U literaturi se takvo kretanje koje omogućuju folksonomije često naziva *pivot browsing*, što označava „(...)kretanje informacijskim prostorom na način da se izabiru nove referentne točke (*pivot*) za istraživanje sistema“ (Smith, 2008: 105. U sustavima korisničkih oznaka tri glavne referentne točke za pregledavanje su dakako korisničke oznake, korisnici i izvori. Takvo kretanje omogućuje bogatstvo pristupnica i mogućih putanja kojima korisnici mogu ući i kretati se sistemom u potrazi za informacijama.

frekvenciju njihova pojavljivanja (oznaka predložena većim slovima učestalija je, odnosno popularnija od drugih). „Oblaci oznaka stoga vizualno predložavaju tri dimenzije folksonomije istovremeno: korisničke oznake, njihovu važnost i abecedni poredak“ (Hearst i Rosner, citirano prema Ibid.: 315). Budući da svaka oznaka obično funkcionira kao poveznica, oblaci oznaka ujedno mogu služiti „(...) za navigaciju, funkcionirajući kao zanimljive pristupnice za pretraživanje izvora i korisnika unutar sustava“ (Smith, 2008: 96).



environmentalism **epic** epic fantasy epistemology epistolary **epub** er erotic
ge essay **essays** ethics ethnography etiquette **Europe** I
n Everyman's Library evil **evolution** ex-library exercise exhibition **exl**
tion explorers **f** fables faerie **fairies** fairy tale **fairy tales** fait
fiction fantastique **fantasy** fantasy fiction fantasy-sci-fi Fantasy
hers **favorite** favorite author **favorites** fbi fear **feelings** female
inist feminist theory **fiction** Fiction - Novel fiction/literature **field** gui
dition first in series first printing fish fishing fitness Florence **Florida**
:/mythology folktale **folktales** **food** food and drink food history food wr
Realms fr **France** **free** freebie freedom Freemasonry **French** Fi
ature French Revolution **friends** **friendship** frogs from Goc
entia - garden **gardening**

Slika 1. Isječak oblaka oznaka na stranici za društveno čitanje LibraryThing.


Preuzeto sa:
<https://www.librarything.com/tagcloud.php>

Oblaci oznaka također ukazuju na zanimljiv fenomen koji se pokazao svojstven folksonomijama. Naime, na nekom mrežnom mjestu na kojem postoji velik broj korisničkih oznaka u oblak obično ulaze samo one s visokom učestalošću pojavljivanja, odnosno oznake koje su korisnici dodijelili dovoljan broj puta da se mogu mjeriti s onim najpopularnijima koje će se u oblaku vizualizirati posebno istaknute veličinom ili bojom. Obično se već na prvi pogled može vidjeti da su najistaknutije oznake relativno malobrojne naspram ostalih koje se pojavljuju u oblaku, kao i onih koje su ostale izvan. Iz vizualizacije se stoga može očitati raspodjela korisničkih oznaka na pojedinoj platformi za koju su istraživanja pokazala da u najvećem broju slučajeva slijedi obrazac Paretove distribucije ili zakon potencije (*power law*) koji se pojavljuje kao vrlo čest uzorak u internetskom okruženju, a koji možemo objasniti kako slijedi: „Zakon potencije je distribucija koju karakterizira mali broj elemenata koji se pojavljuju visokom učestalošću i većina elemenata s niskom učestalošću“ (Ibid.: 52), konkretnije, u slučaju folksonomija. „Nazivi koji se koriste kao korisničke oznake obično se pokazuju distribuirane prema zakonu potencije – nekoliko iznimno popularnih i većina koja se koristi vrlo rijetko“ (Tonkin citirano prema Peters, 2009: 171). *Power law* krivulja pokazat će stoga samo nekoliko

korisničkih oznaka visoke frekvencije u takozvanoj kratkoj glavi (*short head*) i velik broj rijetko korištenih oznaka u dugom repu (*long tail*).



Slika 2. Primjer krivulje zakona potencije (*power law*). Zelena boja prestavlja tzv. *short head* visokofrekventnih elemenata, a žuta elemente niske učestalosti pojavljivanja – *long tail*.



Slika 3. Prikaz distribucije korisničkih oznaka dodijeljenih nasumično odabranoj knjizi (Ana Karenina Lava Nikolajeviča Tolstoja) na stranici Goodreads.

Taj se fenomen u slučaju korisničkog označivanja objašnjava na različite načine pri čemu je razvidno da se u prvom redu tiče karakterističnih ponašanja samih korisnika prilikom označivanja, posebice sociološke pojave koja se ponekad spominje kao Matejev efekt, nazvanoj prema glosi iz Evanđelja po Mateju, a koji bi u slučaju zakona potencije uočenog u folksonomijama značio jednostavno sljedeće: „Što se više određena korisnička oznaka pojavljuje u informacijskom sustavu, to je veća vjerojatnost da će se pojaviti ponovno“ (Peters, 2009: 173) ili, u inačici poznatoj kao *preferential attachment*: „Jednom kad je korisnička oznaka upotrijebljena, veća je vjerojatnost da će se upotrijebiti ponovo“ (Smith, 2008: 53). S aspekta korisničkog ponašanja to bi moglo značiti da su korisnici skloniji opredijeliti se za već dodijeljene oznake nego smišljati potpuno nove i vlastite, ili za one oznake koje im se nude kao element preporučnog sistema, ukoliko takav postoji.

Konzistentnost distribucije *tagova* u formi koja slijedi zakon potencije nerijetko se objašnjava na još jedan način i to onaj koji nesumnjivo podcrtava jednu od najvećih prednosti

korisničkog označivanja kao takvog (u slučaju da se ne radi o zatvorenom osobnom upravljanju informacijama, već o folksonomijama koje se generiraju suradnički): idejom da ono reflektira takozvanu kolektivnu inteligenciju ili mudrost gomile. Mudrost gomile termin je koji je skovao američki novinar James Surowiecki u djelu *The wisdom of crowds* gdje je temeljna je teza da „(...) agregacija informacija u gomili rezultira odlukama koje (...) su često bolje no one koje bi mogao donijeti jedan član grupe.“⁴ Presjek različitih mišljenja i gledišta stoga se smatra superiornijim od mišljenja jednog, bez obzira na njegovu potencijalnu stručnost, kompetencije i znanja. Taj se presjek u vidu kolektivne inteligencije koja obrazuje folksonomije pokazuje prvenstveno kao statistička činjenica: „Karakteristika kolektivne inteligencije može se nazvati i 'suradničkom inteligencijom', prema Vander Wallu (2008). (...) Ovdje fokus nije prvenstveno na slaganju postignutom putem diskusije, već radije na individualnom utjecaju korisnika na oznake i stoga na folksonomiju u cijelosti. Korisničke se oznake formuliraju prema korisničkim željama te su dodane pojedinom izvoru onoliko često koliko je to potrebno – doduše, samo u širokim folksonomijama. (...) Neovisno o tome traži li se slaganje svjesno unutar gomile ili se implicitno generira iz statističkog prebrojavanja distribucije korisničkih oznaka, konsenzus predstavlja svojevrsnu kontrolu kvalitete. Činjenica da nema centralizirane instancije koja kontrolira korisničke oznake ili koja provjerava njihovu točnost prilikom dodjeljivanja znači da se slaganje koje je postignuto putem zajednice mora razumijevati kao kontrola kvalitete“ (Peters, 2008: 167-168). Drugim riječima, kolektivna inteligencija koja se iskazuje prilikom sumiranja individualnih korisničkih odabira u označivanju, a čija konačna distribucija najčešće prati model zakona potencije, postiže rezultat sa stupnjem kvalitete koji će u svakom slučaju odstupati od onog koji može ostvariti pojedinac koji označuje, pa radilo se i o profesionalcu – informacijskom stručnjaku. Kolektivna inteligencija manifestna u folksonomijama pokazuje se stoga kao jedna od njenih ponajvećih prednosti.

Upravo je tema o prednostima i nedostacima korisničkog označivanja među najjačim pokretačima rasprava oko folksonomija, posebice s obzirom na njihovu moguću integraciju među modele sadržajnog označivanja koji se koriste u tradicionalnim AKM ustanovama, ali i mogućnostima njihove upotrebe u indeksiranju informacija na internetu. Prednosti i pozitivne strane folksonomija mogu se sumirati na tragu Isabelle Peters:

⁴ https://en.wikipedia.org/wiki/The_Wisdom_of_Crowds

- „Autentično reflektiraju korisnički jezik te stoga rješavaju 'problem rječnika za označivanje'
- Dozvoljavaju različite interpretacije te stoga premošćuju 'semantički jaz'
- Proširuju pristup informacijskim izvorima
- Slijede liniju korisničkih želja
- Jeftini su oblik označivanja sadržaja
- Raspodjeljuju teret označivanja na više aktera
- Kvaliteta im raste što više korisnika sudjeluje
- Jedina su mogućnost za označivanje nepreglednog broja informacija na internetu
- Sastoje se od naziva koji mogu služiti za razvoj i održavanje ontologija i kontroliranih rječnika
- Prenose kontrolu kvalitete informacijskih izvora na korisnike
- Dopuštaju specifično pretraživanje, kao i pregledavanje
- Registriraju i prihvataju neologizme
- Doprinosu identifikaciji zajednica i 'malih svjetova'
- Stvaraju bazu oznaka, korisnika i izvora za preporučne sisteme
- Senzibiliziraju korisnike za označivanje sadržaja“ (Ibid., 2009: 218).

Iste karakteristike fleksibilnosti, otvorenosti, semantičke i lingvističke raznolikosti te nedostatka kontrole i normalizacije iz kojih proizlazi većina gore navedenih jakih strana korisničkog označivanja (i posljedično folksonomija) uzroci su nekih od njihovih najvećih mana ili slabih točaka:

- „Nedostatak kontrole vokabulara
- Nedostatak definiranih relacija između oznaka
- Nedostatak eksplicitno definiranih svojstava oznaka
- Nepostojanje edukacije i edukativnih materijala za korisnike
- Označivanje korisničkim oznakama prvenstveno za vlastite svrhe“ (Banek Zorica, Špiranec i Zauder 2007: 195).

Problem gotovo stihijskog označivanja informacijskih izvora oznakama koje korisnici dodjeljuju prema vlastitom nahođenju posebno se stoga odražava u činjenici da za razliku od kontroliranih

rječnika ili normaliziranih sustava za označivanje kao što su tezauri, klasifikacije ili taksonomije, u folksonomijama nema eksplicitno definiranih semantičkih relacija među upotrijebljenim terminima. Posljedično, gotovo se neizostavno javljaju problemi poput nerazriješenih homonima, polisemije i sinonimije, potom „(...) oznaka s pogreškama u pisanju, kratica, inicijalizama i akronima, neologizama, *slanga* i žargona, upotrebe nealfabetskih znakova, različitih gramatičkih oblika oznaka te homografa“ (Thomas, Caudle i Schmitz 2010: 225), nazvanima *trashy* ili *messy tags*, odnosno zbrkanim ili problematičnim korisničkim oznakama koje u stvari ne predstavljaju relevantne pristupnice izvorima u pitanju, zbog čega ne ostvaruju cilj sadržajnog označivanja u totalitetu reprezentacije sadržaja i osiguravanja pretraživosti i pronalaženja informacija. Ukoliko se ovim fenomenima pribroji pojava korisničkog označivanja u obliku *spamova*, odnosno *spagginga* „(...) kada korisnici svjesno označavaju neadekvatnim oznakama ili koriste popularne oznake kako bi povećali promet na izvorima koji su postavili“ (Peters, 2009: 224), pokazuje se da određen dio korisničkog označivanja doista može predstavljati problem u pogledu adekvatnog indeksiranja i pretraživanja na razini datog sustava. Ovdje valja naglasiti i činjenicu da je velika količina dodijeljenih korisničkih oznaka personalna, odnosno osobne naravi – naime, korisnici u velikom broju slučajeva označuju izvore prvenstveno radi zadovoljavanja vlastitih informacijskih potreba, skladištenja te omogućavanja pretraživanja i ponovnog pretraživanja interesantnih izvora za sebe. Na slici 3 prikazan je isječak liste oznaka koji su korisnici dodijelili odabranom izvoru na jednoj stranici za društveno čitanje – u ovom se slučaju radi o knjizi *Ana Karenjina* Lava Nikolajeviča Tolstoja⁵ - koju su korisnici na stranici Goodreads označavali iznimno osobnim i idiosinkratičnim oznakama, kao što su „to-read“, „favorites“, „own“, „books-i-own“, „never-finished“ ili „all-time-favorites“ koje predstavljaju odnos individualnog korisnika – čitatelja prema izvoru te stoga imaju potencijalno nisku pristupnu vrijednost za ostale korisnike koji pretražuju izvore.

⁵ Ista lista oznaka upotrebljena je za ilustraciju krivulje zakona potencije na sl. 2.

Anna Karenina > Top Shelves

Top shelves for Anna Karenina (showing 1-100 of 23,756)

to-read	436,383 people	2015	297 people	didn't finish	122 people
classics	12,991 people	my-ebooks	280 people	tolstoy	122 people
fiction	4,905 people	2012	252 people	history	122 people
favorites	4,546 people	to-read-classics	250 people	all-time-favorites	122 people
classic	2,036 people	2014	248 people	russian-classics	120 people
own	1,780 people	ebooks	246 people	own-it	116 people
books-i-own	1,326 people	unfinished	243 people	rory-gilmore	115 people
russian	1,310 people	default	235 people	e-books	115 people
owned	1,279 people	library	230 people	re-read	113 people
romance	1,153 people	ebook	229 people	never-finished	111 people
literature	1,082 people	1001	214 people	gilmore-girls	109 people
historical-fiction	1,060 people	on-hold	205 people	leo-tolstoy	108 people
russian-literature	1,001 people	my-library	203 people	favorite-books	104 people
russia	937 people	audiobook	200 people	2010	103 people
kindle	623 people	adult	189 people	the-classics	102 people
novels	566 people	2017	186 people	classici	101 people
russian-lit	500 people	audiobooks	185 people	must-read	99 people
currently-	499 people	literary-fiction	183 people	audible	96 people
		adult-fiction	182 people		

Slika 4: Isječak liste najpopularnijih oznaka ("top shelves") koje su korisnici dodijelili knjizi Ana Karenjina na stranici za društveno čitanje Goodreads.

Izvor:
<https://www.goodreads.com/work/shelves/2507928>

Analiza korisničkih oznaka na razini sustava kakve su stranice za društveno čitanje bit će provedena u nastavku ovoga rada.

2.3. Recenziranje i ocjenjivanje


Zajedno s najučestalijim, a s pozicije pretraživanja informacija možda i najkorisnijim oblicima sadržajne obrade kao što su označivanje klasifikacijskim oznakama, predmetnim odrednicama, deskriptorima ili ključnim riječima, a kojima suvremeni pandan u elektroničkom okruženju predstavljaju korisničke oznake, tradicionalna obrada poznaje i druge, duže tekstualne oblike obrade u prirodnome jeziku. Te oblike Katica Tadić svrstava pod kišobran pojam dokumentacijske obrade: „Dokumentacijska obradba (rabi se i termin informacijska obradba, vezano uz uporabu elektroničkih računala) sadržajna je obradba dokumenata. Njome se obrađuju bitni pojmovi koji tvore sadržaj određenog dokumenta (primjerka građe), i na osnovi toga se izrađuju razne vrste sekundarnih i tercijarnih publikacija“ (Tadić, 1994: 91). Među tako nastalim rezultatima sadržajne obrade valja spomenuti anotaciju koja se određuje kao. „(...) kratak prikaz sadržaja primarnog dokumenta, iskazan opisno (deskriptivna anotacija) ili kritički. Kritička anotacija vrednuje primarni dokument“ (Ibid.). Anotacijski model pokazao se prijemčiv i u sklopu korisničke sadržajne obrade informacijskih izvora na mreži, s time da u toj varijanti on poprima određene karakteristike književnokritičkog žanra recenzije (*review*) te se na njega obično i referira navedenim terminom.

U okruženju suradničkog *weba* recenzije, uz bok korisničkom označivanju i ocjenjivanju (*rating*), predstavljaju učestali model korisničkog pristupa sadržajnoj obradi. Ponekad se govori

o suradničkoj sadržajnoj obradi (*collaborative annotation*) ili o društvenom označivanju (*social annotation*) koji „(...) je proces kojim korisnici weba upotrebljavaju *ključne riječi ili druge tekstualne oblike na prirodnom jeziku* kako bi kategorizirali, opisali, komentirali ili ocijenili informacijske izvore na internetu (Su et al. 2010.). Dijeljenjem označenih informacijskih resursa, korisnici weba mogu suradnički organizirati i pretraživati izvore, steći jasnije i dublje razumijevanje izvora te se mogu stvoriti posebne interesne skupine oko izvora“ (Wu, Xu i Yu, 2016: 178-179, kurziv moj). Recenzije korisnika i korisničke ocjene danih izvora, proizvoda ili artefakata različite vrste doista se mogu susreti diljem Weba 2.0, počevši od primjerice blogova (usp. Yun i Wen, 2014) na kojima je recenziranje vrlo učestala pojava do komercijalnih stranica poput E-baya ili Amazona koje se koriste mogućnostima komentiranja i ocjenjivanja u marketinške i promotivne svrhe. Recenzije se mogu odrediti kao više ili manje elaborirana tekstualna predočavanja sadržaja izvora o kojem je riječ kroz subjektivnu prizmu mišljenja, dok ocjene imaju oblik kvantitativnih informacija o stavovima korisnika, koje se obično dodaju na bazi brze odluke (usp. Zuccala et al., 2015: 333). Može se pretpostaviti da su brzina i jednostavnost ocjenjivanja – korisnici obično tek povlačenjem miša „popunjavaju“ zvjezdice priložene uz neki izvor kako bi dodali svoju ocjenu u rasponu od jedan do pet – među ključnim čimbenicima zašto je mnogo veći broj korisnika sklon takvom izražavanju stava od pisanja recenzija koje zahtijevaju nešto više vremena, truda i involviranosti.

Slika 5. Uobičajeni model ocjenjivanja knjiga zvjezdicama u rasponu 1-5, preuzet sa stranice Goodreads.

Izvor: <https://www.goodreads.com/>



Istraživanja korisničkog ponašanja i motivacija u pogledu recenziranja pokazala su da nekoliko faktora utječu na učestalost i raširenost korisničkih komentara i recenzija. Prema Huang i Yang (2010., 2014.), recenzije i komentari korisnika predstavljaju primjere takozvane eWOM, odnosno elektroničke usmene riječi (*electronic word of mouth*), a upravo je usmena riječ najučestaliji oblik preporuke općenito i onaj kojem su ljudi najčešće skloni vjerovati i u nevirtualnim okruženjima. Glavni motivi korisnika koji pišu recenzije na internetu može se pobrojati u četiri glavne kategorije: želja za dijeljenjem vlastitih iskustava ili mišljenja s drugima, izražavanje negativnih emocija, želja za društvenom interakcijom (sudjelovanje u

online zajednicama) te osobna uključenost u proizvode ili situacije (usp. Ibid., 2010: 806). Ne smije se zaboraviti ni činjenica da se više ne radi isključivo o službenim ili profesionalnim komentatorima ili recenzentima, već je danas ta mogućnost pružena svim zainteresiranim korisnicima. Tako možemo supostaviti tradicionalni model u kojem informacijski stručnjak (knjižničar) anotira informacijske izvore (knjige) suvremenom demokratskom modelu: „Pojava interneta lišila je stručnjake njihovih ekskluzivnih prava da pišu recenzije knjiga. Svaka zainteresirana stranka može pisati i objavljivati vlastita mišljenja na web stranicama“ (Ibid: 805). Upravo su knjige i dalje vrsta informacijskog izvora koji se često recenzira na internetu, bilo na blogovima, forumima ili pak na sve popularnijim stranicama za društveno čitanje: „Od pokretanja stranice za društveno čitanje LibraryThing 2005. godine suradnička sadržajna obrada knjiga postaje sve popularnija na raznim društvenim stranicama, kao što su Shelfari i Goodreads (Zhuang i Wu, 2012). Na tim stranicama, aktivnosti suradničke sadržajne obrade uključuju dodavanje korisničkih oznaka, kometiranje te davanje ocjena knjigama“ (Wu, Xu i Yu, 2016: 179). Stranice za društveno čitanje stoga se mogu smatrati egzemplarnima za razmatranje suvremenog korisničkoga pristupa sadržajnoj obradi informacija u cjelosti.

3. STRANICE ZA DRUŠTVENO ČITANJE

3.1. Suradnički informacijski sustavi

Stranice za društveno čitanje (*social reading sites, bookshelf sites, social cataloguing sites*), čija se pojava i rastuća popularnost na internetu bilježi posljednjih desetak godina, mrežna su mjesta koja okupljaju korisnike u zajednice temeljene na dijeljenom interesu – u ovom slučaju radi se, dakako, o knjigama i čitanju. Pod pojmom društvenog čitanja razumijeva se „(...) čitanje koje se događa u virtualnom okruženju, gdje se daje prednost stvaranju zajednica i omogućuje razmjena temeljena na knjizi i čitanju. Općenito, sastajalište za korisnike formira se na internetskoj platformi ili specifičnom softverskom proizvodu koji organizira prostor za razmjenu informacija među korisnicima i za horizontalnu komunikaciju, gdje se djelima pristupa, razmjenjuju se mišljenja o tekstovima, sudjeluje se u grupama za diskusije, i/ili stvaraju pisani komentari te oznake za djela i autore“ (Pouillot, citirano prema Cordon-García et al., 2013: 156-157). Takva su mrežna mjesta očigledno postala moguća tek kad su tehnološke i softverske

inovacije dovele do stvaranja Weba 2.0, odnosno kad su omogućile da korisnik ne bude samo pasivni konzument sadržaja, već da svojim aktivnostima stvara i organizira sadržaje na internetu. Stranice za društveno čitanje stoga treba razmotriti u svjetlu šireg fenomena kojeg su dio: uz servise za društveni *bookmarking* kao što je Del.icio.us, stranice za e-kupovinu poput Amazona ili Etsyja, komercijalnih informacijskih servisa koje koriste subjekti iz poslovne sfere, servisa za dijeljenje glazbe te drugih multimedijских sadržaja poput fotografija (Flickr, Pinterest) i videa (Youtube), stranice za društveno čitanje nedvojbeno možemo ubrojiti u kategoriju suradničkih informacijskih sustava. Generiranje i sve veću popularnost navedenih sustava Isabella Peters objašnjava kako slijedi: „Značajan porast sadržaja koji stvaraju korisnici povećao je potražnju za odgovarajućim metodama i sredstvima za pohranu i pretraživanje navedenih sadržaja. Kako bi zadovoljili tom zahtjevu, tvrtke i kompjuterski stručnjaci razvili su suradničke informacijske sustave kao što su društveni *bookmarking* ili sustavi za dijeljenje fotografija i videa, koji omogućavaju korisnicima da pohranjuju i objavljuju vlastite informacijske izvore, kao i da ih indeksiraju vlastitim oznakama“ (Peters, 2009: 1). Upravo je potonje posebno važno jer suradnički informacijski sustavi „(...) uglavnom služe upravljanju osobnim izvorima, ali također omogućuju suradničko stvaranje javne baze podataka dostupne svim (ako je potrebno, registriranim) korisnicima. Nadalje, izvore na suradničkim informacijskim sustavima indeksiraju korisnici, odnosno, izvori su predstavljeni na platformi putem korisničkih oznaka (*tagova*)“ (Ibid.: 19-20). Utoliko se može reći da postoji snažna međuovisnost folksonomija i suradničkih informacijskih sustava, štoviše, folksonomije se smatraju nezaobilaznom komponentom potonjih.

Na suradničkim informacijskim sustavima obično se odvija cjelokupni proces korisničke sadržajne obrade ocrtan u prethodnom poglavlju: korisnici ne samo da objavljuju vlastite sadržaje, već im na raspolaganju stoji i niz funkcionalnosti kojima mogu obraditi sadržaje korisničkim oznakama, ocjenama ili recenzijama, stvoriti na taj način nove pristupnice za pretraživanje i pronalaženje informacija te pritom sudjelovati u stvaranju mreže koja zahvaljujući i aktivnostima sadržajne obrade poprima formu virtualne društvene zajednice.

Razlike u funkcionalnostima postoje među različitim vrstama suradničkih informacijskih sustava, kao i među pojedinim platformama koje su istog tipa ili namjene. Međutim, može se zaključiti da im je jedna od glavnih zajedničkih točaka tripartitna struktura svojstvena

folksonomijama – korisnici, izvori te korisničke oznake čije međudjelovanje omogućuje specifično pretraživanje, pregledavanje i pronalaženje informacija. U tu svrhu, suradnički informacijski servisi redovito razvijaju neku vrstu preporučenih sistema. Oni mogu biti automatski, u kojem slučaj predstavljaju „(...) aplikacije koje pomažu korisnicima u pronalaženju korisnih objekata na način da automatski reduciraju područje izbora na one najrelevantnije“ (Balby Marinho et al., 2012: 7). Rezultat ponovno može biti bilo koji od entiteta koje tvore tročlani raster: korisniku se preporučuju drugi korisnici sličnih interesa, preporučuju mu se izvori koji mogu odgovarati njegovoj informacijskoj potrebi te korisničke oznake koje mogu voditi do relevantnih izvora ili korisnika (usp. Ibid.: 8-9). Međutim, uz algoritme koji na taj način automatski provode proces filtriranja informacija za pojedinog korisnika, suradnički informacijski sustavi koji počivaju na korisničkom pristupu sadržajnoj obradi, na tagiranju, ocjenjivanju te recenzijama, omogućuju stvaranje korisničkih preporučenih sistema oblikovanih pomoću elektroničke usmene riječi te bazirane na sasvim ljudskom faktoru povjerenja među korisnicima (usp. Zuccala et al., 2015: 333; Naik, 2012: 321).

Prije no što se detaljnije razmotri na koji način od toga profitiraju stranice za društveno čitanje - suradnički informacijski sustavi koji su u fokusu ovoga rada - potrebno je razmotriti svojevrsan kulturni obrat čiji je jedan od simptoma nepregledno rastući broj njihovih korisnika.

3.2. Nova paradigma čitanja

Pišući o povijesti čitanja kao prakse koja se na razne načine mijenja tijekom vremena, Guglielmo Cavallo i Roger Chartier napisali su: „Odbijajući ideju da tekst postoji po sebi neovisno od bilo koje materijalne manifestacije (...) trebamo imati u vidu da niti jedan tekst ne postoji izvan fizičke podloge koja mu omogućava da bude čitan (ili slušan) niti izvan okolnosti u kojima je čitan ili slušan. Autori ne pišu knjige: oni pišu tekstove koji postaju pisani objekti – manuskripti, zapisi, tiskani predmeti ili računalne datoteke. Sa svim navedenim objektima na različite načine postupaju čitatelji od krvi i mesa čije se čitateljske navike mijenjaju tijekom vremena, mjesta i u odnosu na okruženje“ (1999: 5). Nove čitateljske navike omogućene su također zahvaljujući raznim tehnološkim pronalascima u posljednjih nekoliko desetljeća koji ne samo da su omogućili potupno nove formate knjiga, kao što je elektronička, te potpuno novu hardversku podršku čitanju, kao što su elektronički čitači, već i to da su se sama praksa čitanja i

komunikacijski kanali za razgovore o pročitanoj do te mjere izmijenili da se i u tom pogledu može govoriti o novoj paradigmi. Naspram individualnog suočavanja s knjigom na koju nas je naučio njezin tiskani oblik⁶ do te mjere da se čitanje gotovo samorazumljivo smatra samotnom i subjektivnom djelatnošću, danas se ono profilira kao zajednička društvena praksa. Socijalni karakter čitanja ponovno je zaživio upravo zahvaljujući tehnologiji koja je omogućila do tada nemoguću komunikaciju i razmjenu informacija na globalnoj razini između čitatelja sličnih ili dijeljenih interesa: „Društveno čitanje je posebna komunikativna praksa koja se pojavila kao rezultat novih tehnoloških razvoja, posebice razvoja u elektroničkom izdavaštvu. Čitateljska participacija u procesu (post)produkcije teksta (u obliku *označivanja, podcrtavanja, recenziranja, ocjenjivanja itd.*) daje sasvim novu dimenziju činu čitanja, podijeljenog s istomišljenicima. Kada zahvaljujući internetu dijeljeno čitanje postaje globalno putem interneta, posebno kreirani programi i platforme koji su osmišljeni s ciljem olakšavanja razmjene među čitateljima obogaćuju iskustvo čitanja knjiga i omogućuju čitatelju iskorak daleko izvan uskih krugova tradicionalnih čitateljskih klubova“ (Cordon-García et al., 2013: 143, kurziv moj).

Iako stranice za društveno čitanje s korisničke perspektive u prvom redu predstavljaju osobnu privatnu knjižnicu ili barem virtualnu policu za knjige, upravo činjenica da one putem različitih vrsta korisničke sadržajne obrade osiguravaju pristup, pretraživanje, pronalaženje i dijeljenje informacija među korisnicima omogućuje da se na njima aktivira društvena dinamika. Stoga bi se moglo reći da je vrlo važan uvjet socijalizacije čitanja na internetu upravo ostvarivanje potencijala korisničkog označivanja s naglaskom na “(...) ključno obilježje njihove potpune subjektivnosti. To znači da ne postoje definirane smjernice u sadržajnoj analizi i pravila ili načela iskazivanja označitelja, nego počivaju na potpunoj slobodi i spontanosti u njihovom odabiru. Pojam može imati neograničen broj različitih oznaka što rezultira pluralističkim i višeperspektivnim označivanjem pojedinih izvora. Budući da ne postoje ograničenja u količini oznaka koje se mogu podijeliti nekom izvoru, posredno se postiže visoka informiranost o pojedinom izvoru“ (Špiranec, 2014: 10). To je označiteljsko višeglasje usko povezano uz socijalni karakter suvremenog čitanja, odnosno, moglo bi se općenito zaključiti da se suvremena

⁶ Nerijetko se može naići na konstataciju da se u stvari ne radi o sasvim novom kulturnom modelu, već povratku na izvorište – poznato je da se u vrijeme antike knjiga redovito konzumirala u skupinama i na glas te je čitanje imalo izrazito društveni karakter. Općenito, ponova socijalizacija čitanja kao prakse može se smatrati dijelom takozvane sekundarne oralnosti, termina koji je teoretičar Marshall McLuhan koristio kako bi opisao „(...) način na koji elektronički mediji kao da omogućavaju uspon novim načinima komunikacije koje su svojstvenije oralnim, nego recentnijim pismenim kulturnim modelima“ (Smith: 2008, 17)

paradigma društvenog čitanja pokazuje komplementarnom s novom paradigmom subjektivnog označivanja informacijskih izvora, a ta se podudarnost ponajbolje iskazuje upravo na brojnim stranicama za društveno čitanje.

3.3. Pregled i karakteristike stranica za društveno čitanje

Relativno kratka povijest čitanja na stranicama za društveno čitanje može se pratiti od 2005. godine kada je u rad puštena LibraryThing, do danas jedna od popularnijih stranica. Tijekom godina nicala su brojna slična mrežna mjesta od kojih su neka – kao danas vodeći Amazonov Goodreads - privukla i zadržala znatan broj korisnika, dok su druga kao što je to Shelfari kojeg je također kupio Amazon te ga integrirao u potonji, izbrisane iz šarolikog pejzaža stranica za društveno čitanje. Od stranica koje su opstale valja spomenuti Goodreads, LibraryThing, Anobii, Bookstr, Riffle, BookLikes, i BookBrowse. Popis je do izvjesnog stupnja provizoran i privremen s obzirom na česte modifikacije stranica za društveno čitanje, posebice onih koje nisu među najjačima. Bez obzira na odabir egzemplarnih stranica, sve se one do određene mjere razlikuju po funkcionalnostima i opcijama koje nude korisnicima, ali su srodne po temeljnoj namjeni i s njom povezanim značajkama: omogućavanje stvaranja vlastite virtualne knjižnice uz neku vrstu sadržajne obrade u formi korisničkih oznaka, recenzija i ocjenjivanja, posljedične mogućnosti pretraživanja i pronalaženja informacija te društveni karakter. Stoga se može konstatirati sljedeće: „Karakteristike pojedinih platformi su vrlo slične. Ključna razlika leži u prirodi tekstova koji se komentiraju te u njihovom originalnom formatu. U većini slučajeva čitatelj ili čitateljica komentira djelo koje je pročitao/la, koje trenutno čita ili koje želi pročitati premda se sam dokument ne nalazi na platformi. Platforma omogućava korisnicima da objave svoja mišljenja o djelima, na taj način omogućavajući da se ona dijele s drugim korisnicima pa čak i da se pronađu istomišljenici na temelju njihove zabilježene povijesti čitanja. (...) Ovdje također možemo govoriti o društvenoj mreži čitatelja. Korisnici objavljuju komentare o djelima, citate, ocjene itd.“ (Cordon-Garcia et al., 2013: 166).

Gore navedene stranice razmotrit će se pobliže u nastavku, posebice imajući u vidu različite mogućnosti korisničke sadržajne obrade - označivanje, komentiranje i ocjenjivanje – kakve nude svojim korisnicima.

Stranica za društveno čitanje koja je u ovom trenutku nesumnjivo najpopularnija među postojećima je Amazonov Goodreads. Prema podacima dostupnima na stranici, Goodreads broji 55 milijuna članova, a u svojoj bazi sadrži 1,5 milijardu knjiga te 50 milijuna recenzija, stoga svakako stoje rečenice da se radi o „(...) najvećoj stranici za čitatelje i preporuke knjiga na svijetu“⁷. Goodreads je osnovan 2007. godine te se tijekom proteklog desetljeća mijenjao i razvijao u mjesto koje čitateljima nudi organizaciju vlastitih virtualnih „polica za knjige“, mogućnosti da pronađu knjige po vlastitom ukusu na temelju korisničkih i automatskih personaliziranih preporuka te da se umreže s čitateljima srodnih književnih preferencija. Aspekt organizacije znanja na Goodreads sučelju pronalazi se pod opcijom *Moje knjige (My books)* kojom je čitatelju omogućen pregled i promjene na vlastitoj privatnoj knjižnici. Knjige su ovdje raspoređene po takozvanim policama (*bookshelves*) pri čemu se radi o zbirkama podijeljenima prema oznakama koje im dodjeljuje sam korisnik. Tek su tri police, odnosno tri korisničke oznake zadane: pročitano (*read*), trenutno čitam (*currently reading*) te želim pročitati (*to read*), dok sve ostale ovise o korisniku. Na taj se način obrazuje personomija koja sekundarno stvara folksonomiju stranice. Vlastite police (korisničke oznake) moguće je prikazati u takozvanom „oblaku polica“ te ih u njemu sortirati bilo prema „veličini polica“ (*shelf size*), odnosno frekvenciji uporabe, bilo prema imenu police (*shelf name*), to jest abecednim slijedom. Uobičajeni prikaz polica uključuje brojne podatke o knjigama uključujući naslov, autora, prosječnu ocjenu na razini stranice, korisnikovu ocjenu, police (korisničke oznake), period čitanja te datum dodavanja, a moguće je vidjeti i dodatne informacije kao što su komentari, ISBN, recenzije i tako dalje.

Pretraživanju informacija pristupa se putem opcije *Browse* koja korisniku nudi velik broj mogućnosti: moguće je pregledavati preporuke, liste knjiga koje su formirali drugi korisnici prema nekom vlastitom kriteriju (*Listopia*), nova izdanja, nagrađene naslove itd. ili pretraživati stranicu prema omiljenim žanrovima koje korisnik prema vlastitim sklonostima odabire prilikom registracije, kao što su dječje knjige, klasici, kuharice, fikcija i slično.

Inherentni socijalni aspekt Goodreadsa postaje eksplicitnim kada se odaberu opcije *Grupe (Groups)*, koje su stvorene od strane korisnika i koje tvore korisnici, a radi se o skupinama okupljenima oko specifičnog interesa, naziva poput *The Mystery, Crime and Thriller Group* ili

⁷ <https://www.goodreads.com/about/us?rel=nofollow>

Indian Readers kojima se također mogu dodijeliti korisničke oznake te su na isti način i pretražive. Korisnički su označene i Diskusije (*Discussions*), odnosno razgovori forumskog tipa o autorima ili knjigama, te Citati (*Quotes*) gdje čitatelji mogu pronaći široki spektar raznih tekstualnih isječaka.

S obzirom da je mogućnost korisničkog označivanja iskorištena ne samo za indeksiranje knjiga, već i grupa, razgovora, citata i lista te činjenice da su poneke korisničke recenzije napisane na Goodreadsu toliko popularne da se nerijetko na tražilicama nalaze na prvim mjestima (usp. Naik, 2012: 321) može se zaključiti da je Goodreads prepoznao i iskoristio potencijal korisničke sadržajne obrade gdje god je to moguće: „Jedna od najznačajnijih karakteristika Goodreads-a jest mogućnost da uzmemo razbacane police knjiga u našoj radnoj sobi te ih pretvorimo u organizirani komad digitalne umjetnosti. U tu svrhu, Goodreads nudi niz organizacijskih alata uključujući stavljanje na police, sortiranje i meta-tagiranje.“ (Dionisio, 2014: 20).

Ako Goodreads ima prvenstvo na temelju popularnosti, kronološki je prvak stranica za društveno čitanje LibraryThing koja postoji od 2005. godine. Zanimljiva je ne samo individualnim korisnicima, već i knjižnicama koje također mogu otvoriti vlastiti račun. Štoviše, program LTFL, odnosno, *LibraryThing for Libraries* (LibraryThing za knjižnice) omogućuje knjižnicama da implementiraju korisnički generirane podatke o knjigama u svoje mrežne kataloge: „LibraryThing za knjižnice omogućuje knjižnicama da obogate vlastite kataložne zapise s oblacima oznaka, preporukama sličnih knjiga te poveznica na druga izdanja i prijevode djela na temelju baze podataka LibraryThing“ (Voorbij, 2012: 197). Ovdje valja napomenuti da se korisničke oznake pripremaju za uključivanje u knjižnične kataloge na način da prolaze kontrolu prikladnosti i korisnosti od strane informacijskih stručnjaka te se problematične oznake istom isključuju (usp. Ibid.; Smith, 2008: 134). LibraryThing broji 2 milijuna korisnika, 113 milijuna kataogiziranih knjiga, 136 milijuna korisničkih oznaka, 3 milijuna recenzija te preko 17 milijuna ocjena.⁸ Korisniku je omogućeno da dodaje knjige u svoju virtualnu knjižnicu koristeći se pritom Amazonovim metapodacima, metapodacima kataloga Kongresne knjižnice ili preko tisuću drugih knjižnica u mreži, pri čemu se na police mogu smjestiti ne samo knjige, već i filmovi i glazba. Tvorci LibraryThing-a jasno naglašavaju

⁸ <http://www.librarything.com/zeitgeist>

važnost društvene dimenzije i mogućnosti koje proizlaze iz *web* suradnje te značaj korisničkog označivanja: „Budući da svi korisnici katalogiziraju *online*, ujedno katalogiziraju zajedno. Možete dati svoj doprinos u obliku korisničkih oznaka, ocjena i recenzija za knjigu ili u stvaranju korpusa činjenica o knjizi ili autoru kao što su imena likova i nagrade ('zajedničko znanje'), sudjelovati u forumima za članove ili se uključiti u Program ranih recenzija (*Early reviews program*). Svi profitiraju od svačije aktivnosti.“⁹

Kao što je to uobičajeno na stranicama za društveno čitanje, korisnik može dodavati knjige na svoje virtualne police tako da ih pronade u bazi na temelju pretrage po naslovu, autoru i ISBN-u ili ih može dodati ručno, odabrati prikaz u obliku popisa ili vizualno privlačniji slijed naslovnica, može pretraživati i sortirati knjige, stvarati zbirke, mijenjati podatke o knjigama, printati svoj katalog, pisati recenzije, ocjenjivati i dodavati korisničke oznake. Na LibraryThingu postoji i sustav za preporuke za naslove koji bi mogli zanimati pojedinog korisnika, a omogućuju mu i da istražuje recenzije te liste knjiga koje su popisali korisnici. Može sudjelovati u grupama prema svojem interesu (*Groups*) i forumima ili zaigrati LibraryThing rulet koji korisniku preporučuje drugog korisnika, autora, naslov, ali i recenziju i korisničku oznaku na temelju slučajnog odabira.

Velik je naglasak stavljen na korisničke oznake što je vidljivo i iz varijeteta oblaka koji su korisniku dostupni za pregledavanje. S jedne strane, tu su oblaci oznaka koje se odnose na naslove zastupljene na korisnikovim virtualnim policama: standardni oblak oznaka, autorski oblak te zrcalo korisničkih oznaka (*tag mirror*) koje ilustrira kako je cijela LibraryThing zajednica označila iste knjige. S druge strane, vidljiva je korisnička aktivnost označivanja na razini cijele stranice: oblak oznaka, autorski oblak te oblaci zajedničkog znanja (*common knowledge cloud*) koji predstavljaju preglede frekventnih činjenica vezanih uz sve dokumente u bazi podataka, kao na primjer dvjesto najpopularnijih serijskih publikacija, dvjesto mjesta koji su najviše spominjana u književnim djelima, dvjesto najčešćih imena likova/osoba i tome slično.

Na Anobiiju, jednoj od dugovječnijih stranica za društveno čitanje stvorenoj 2006. godine koja je do danas okupila nešto manje od milijun i petsto tisuća registriranih korisnika i gotovo 49 milijuna knjiga, u mnogo je manjoj mjeri iskorišten potencijal korisničke sadržajne obrade. Opcije manipuliranja knjigama i povezivanja s drugim korisnicima jednako su tako

⁹ <http://www.librarything.com/tour/>

ograničene: početna stranica sadrži *stream* koji pokazuje aktivnosti drugih članova, a paralelno se pokazuju elementarne informacije o samom korisniku. Opcija Moja polica (*My shelf*) vizualno je privlačna te sadrži slike omota knjiga koje je korisnik odabrao za svoje zbirke. Za razliku od Goodreads, ovdje nema predeterminiranih polica/oznaka, korisnik ih sve stvara sam. Knjige se mogu svrstati i poredati prema kriterijima progresa (pročitane, nepročitane, trenutno se čitaju), prema jeziku publikacije ili autoru. Oznake koje korisnik dodjeljuje knjigama moguće je vidjeti u obliku liste ili u obliku oblaka. Međutim, na prikazu same knjige nema korisničkih oznaka koje su joj dodijeljene na razini stranice, već samo slijed recenzija te ocjene – prosječna i korisnikova.

Anobii, kao i prethodne dvije stranice, sadrži Grupe u kojima korisnik može sudjelovati, a dostupno je i pregledavanje sadržaja putem opcije *Collections* koja obuhvaća ono što se na drugim stranicama uvriježeno naziva listama – popisima koje stvaraju korisnici prema nekom vlastitom kriteriju, kao što su Tisuću besplatnih e-knjiga, Knjige koje se moraju pročitati itd.¹⁰

Libib, kao i LibraryThing, omogućuje korisnicima da osim knjiga u svoje zbirke uključuje i filmove. O sebi kažu da su „sistem za upravljanje privatnim i manjim institucionalnim knjižnicama“¹¹. U skladu s time, iako se radi o stranici za društveno čitanje nalik prethodno prezentiranima, sučelje Libiba ostavlja dojam prvenstveno organizacijskog alata, a tek sekundarno mrežnog mjesta s društvenom funkcijom – virtualna knjižnica u prvom je planu. Točnije rečeno knjižnice, jer korisnik može stvoriti i u isto vrijeme upravljati njih nekoliko. U knjižnici se knjige mogu prikazati u popisu ili redanjem slika omota, u svakom je slučaju moguć jedino prikaz abecednim poretком naslova, silazno ili uzlazno. Korisnik može ocijeniti dokument u pitanju, napisati recenziju ili dodati korisničke oznake koje se mogu prikazati u obliku popisa. Opcija njihovog pregleda u oblaku ne postoji, kao ni pregled svih korisničkih oznaka dodanih određenoj knjizi. Moguće je tek odabrati opciju koja izlistava sve recenzije napisane o datoj knjizi, kao i *postovi* korisnika u kojima je knjiga spomenuta.

Slična elementarna stranica s malim brojem mogućnosti konzumiranja i manipuliranja sadržajima za korisnike je Riffle. Riffle nudi takozvane *Reading updates*, to jest, prikazuje korisniku vijesti te nove aktivnosti povezanih korisnika. Stranica omogućuje da se pregledavaju nasumične preporuke naslova i popisa naslova koje su kreirali korisnici putem opcije *Browse*

¹⁰ <http://www.anobii.com/collections>

¹¹ <https://www.libib.com/>

books, kao i pretraživanje po autorima raspoređenima prema prethodno zadanim žanrovskim kategorijama po kojima su razvrstani i korisnici, s kojima se moguće povezati na temelju tako prezentiranog zajedničkog interesa. I ovdje korisnici mogu stvarati i pretraživati liste, a stranica prenosi i vijesti o novim izdanjima¹².

Korisnik dodaje naslove na svoju virtualnu policu te ih može označiti s pročitao sam (*have read*), trenutno čitam (*currently reading*) te želim čitati (*want to read*). Riffle nudi i brzu opciju preporučujem (*reccomend*) koja je također svojevrsna klasifikacija prema korisnikovom subjektivnom sudu. Uz to je omogućeno standardno ocjenjivanje dodavanjem zvijezdica te pisanje recenzija o pročitanim. Pregled naslova koji se nalaze na korisnikovoj polici uključuje i pregled svih recenzija napisanih na razini stranice, kao i svih korisnički generiranih lista na kojima je spomenuta dotična knjiga te popis čitatelja koji su je pročitali, trenutno čitaju ili ju preporučuju. Radi se o sustavu koji uz automatske preporuke omogućuje i takvo pregledavanje dokumenata i korisnika koji bi mogli biti zanimljivi ili korisni. Međutim, mogućnosti pretraživanja uz navigaciju po korisničkim oznakama nema zato što Riffle ne nudi mogućnost korisničkog označivanja kao takvog.

Izostanak korisničkog označivanja kao važnog djela korisničke sadržajne obrade na stranicama za društveno čitanje osjeća se i na stranici Bookstr, donedavno poznatoj pod nazivom The reading room. Podatci na stranici kažu da je osnovana 2010. godine te da trenutno broji 1,6 milijuna članova. Bookstr nudi vijesti iz svijeta književnosti u obliku članaka, kao i pretraživanje novih izdanja i novih knjiga razvrstanih po prethodno zadanim kategorijama kao što su fikcija, ne-fikcija i dječje knjige¹³. Korisnik može pregledavati liste, *Recommendations* kojima mu se nude zanimljivi naslovi na temelju korisničkih ili automatskih preporuka te može čitati recenzije drugih korisnika ili pretraživati citate (*Quotes*). U svojoj virtualnoj knjižnici može knjige označiti, kao i drugdje, prema tome je li ih pročitao, trenutno čita ili želi pročitati (*have read, reading now, want to read*) te ih označiti kao preporučene (*books I loved*). Knjige korisnik može ocijeniti, može napisati recenziju i ponuditi je zajednici korisnika, međutim korisničkog označivanja nema te su knjige eventualno označene generički, kategorijama prethodno definiranim na stranici kao što su popularna fikcija (*popular fiction*) ili filozofija i društvo (*philosophy&society*).

¹² <https://www.rifflebooks.com/>

¹³ <https://www.bookstr.com/latest-releases/new-fiction>

Za razliku od prethodnih, stranica Booklikes, osnovana 2011. godine, kombinacija je bloga i stranice za društveno čitanje.¹⁴ Prilikom registracije korisnik ne samo da odabire književne žanrove koje preferira kao što je to slučaj drugdje, već također želi li pisati blog, koji u ovom slučaju prvenstveno funkcionira kao platforma za pisanje recenzija knjiga, ili se opredjeljuje samo za opciju *Bookshelf* kojom izgrađuje svoju virtualnu knjižnicu. Booklikes omogućuje pretraživanje na temelju metapodataka kakvi su ime autora, naslov, ISBN ili korisničke oznake. Prva razina kategorizacije od strane korisnika u načelu je ista kao i na drugim stranicama – pročitao/la sam (*read*), planiram čitati (*planning to read*) te trenutno čitam (*currently reading*), a knjige se mogu ocjenjivati i recenzirati. Opcijom *Add shelf* dodaju se nove police po nahodjenju korisnika, međutim one ne funkcioniraju kao korisničke oznake – *tagovi* se dodaju zasebno, ali ne služe kategoriziranju knjiga na policama, a pregled knjige ne vodi do ukupnosti korisničkih oznaka na razini stranice - dostupne su samo zadane žanrovske kategorije. Po istim kategorijama pretražuje se ukoliko se odabere opcija *Explore*, čime je korisniku otvoren put za pronalazak novih korisnika, popularnih blogova i recenzija, diskusija ili grupa te prijatelja s kojima će formirati svoju književnu zajednicu. Pretraživanje je moguće izvršiti prema žanrovima ili prema recentnosti – korisniku se mogu prikazati nedavno recenzirane, pregledavane, čitane (*recently reviewed*, *recently looked up*, *read*) ili nove knjige na policama (*new on bookshelves*). Ako se stranica pretražuje ne temelju opcije korisničke oznake (*tags*), rezultati pretraživanja bit će recenzije, članci ili slični tekstovi koji su označeni terminom iz pretrage, međutim oznake koje se prikazuju uvijek su oznake koje je dokumentu dodijelio jedan korisnik. Jedina mogućnost prikaza kojim su na razini stranice sumirane korisničke oznake je opcija *Top tags* koja prikazuje oblak najučestalijih oznaka koji su korisnici dodijelili dokumentima proteklog tjedna.



Slika 6. Oblak najpopularnijih korisničkih oznaka u datom tjednu prezentiran na stranici Booklikes.

Izvor: <http://booklikes.com/top-tags>

¹⁴ <http://booklikes.com/>

Posljednja stranica u ovom pregledu je Bookbrowse koja se ponešto razlikuje od prethodnih, prvenstveno po tome što je na njoj stvaranje vlastite virtualne knjižnice te društveni aspekt sekundaran. Za razliku od netom razmatranih, korištenje stranice Bookbrowse nije besplatno, a sami se predstavljaju kako slijedi: „Bookbrowse je *online* časopis za ljubitelje knjiga, a uključuje recenzije, preglede, članke o knjigama, razgovore s autorima, vodiče za čitanje i još mnogo toga“.¹⁵

Uz recenzije i vijesti iz književnosti u prvom planu, Bookbrowse ipak nudi opciju stvaranja vlastite niše pročitanih, čitanih ili željenih knjiga u sklopu opcije koja se naziva Moj popis čitanja (*My reading list*), a koja korisniku omogućuje pretragu, dodavanje knjiga na police, ocjenjivanje te razvrstavanje u šest zadanih niša, ovisno o stadiju u procesu čitanja (*must read, want to read, currently reading, have read, give as a gift i rejected*). Nevezano s tom razinom razvrstavanja, korisnik može koristiti oznake (*tagove*) za svaku dodanu knjigu te ih može pregledati u vlastitim oblacima oznaka. Oblaci su ujedno jedan od prominentnih načina pregledavanja na stranici – formirani su žanrovski i tematski oblaci, kao i oblaci koji sadrže oznake o mjestu i vremenu radnje.

Međutim, nije se moguće povezivati s drugim korisnicima u svrhu stvaranja virtualne zajednice pa slijedom toga niti u pravom smislu riječi profitirati od korisničke sadržajne obrade u njezinim različitim varijantama. Socijalni aspekt očuvan je tek u obliku književnog kluba (*Bookclub*), odnosno moderiranog foruma u kojem se nalazi svega par aktivnih tema o aktualnim naslovima, dok su zastarjele teme poput razgovora o prošlogodišnjim naslovima zaključane za daljnju diskusiju. Evidentno je da Bookbrowse kontrolira i ograničava uobičajene mogućnosti korisničke sadržajne obrade te je, primjerice, recenziranje ostalo u rukama stručnjaka čije su kvalifikacije obrazložene u biografijama objavljenima na stranici. Korisnik može dati svoju ocjenu, ali je ukupna ocjena uvijek supostavljena ocjenama profesionalaca, dok je korisničko označivanje filtrirano i sortirano prema tematskim, žanrovskim, prostornim i vremenskim kriterijima. Može se pretpostaviti da je razlog tome zahtjev da se održi izvjesna razina kvalitete sadržajne obrade na stranici kojoj pristup nije besplatan, a koja se eventualno može smatrati upitnom ako se ostavi u rukama nestručnjaka i bez ikakve kontrole.


¹⁵ <https://www.bookbrowse.com/information/index.cfm/fuseaction/about/>

Ta je sumnja inherentna velikom broju rasprava o korisničkoj sadržajnoj obradi te će dalje biti razmotrena u sklopu istraživanja korisničkih oznaka na stranicama za društveno čitanje.

4. ISTRAŽIVANJE: KORISNIČKE OZNAKE NA STRANICAMA ZA DRUŠTVENO ČITANJE


Budući da je korisnička sadržajna obrada u svojim varijantama kao što su korisničko označivanje, recenziranje i ocjenjivanje suvremen demokratični pandan sadržajnoj obradi kakvu su tradicionalno obavljali stručnjaci, s pravom se postavlja pitanje koliko navedene prakse doista mogu biti relevantne kao načini organiziranja i predstavljanja informacija te stvaranja adekvatnih pristupnica za dati dokument. Iako je barem mala količina subjektivnosti inherentna svakom indeksiranju koje se obavlja ručno, korisničko označivanje radikaliziralo je njezinu razinu te se u velikoj većini razmatranja korisničkih oznaka i folksonomija dolazi do zaključka da je ipak potrebna izvjesna doza normalizacije ili intervencije u oznake kako bi se predstavljanje znanja i njegova pretraživost optimizirala. Istraživanje koje je poduzeto za potrebu ovoga rada kreće od hipoteze postavljene na tom tragu: korisničke oznake upotrijebljene na stranicama za društveno čitanje ne samo da su subjektivne, već su nerijetko i osobne prirode te samim time problematične za ciljano pretraživanje informacija.

Za istraživanje je odabrana kombinirana kvantitativna i kvalitativna metoda po uzoru na prethodno provedena istraživanja: istraživanje korisničkih oznaka u znanstvenoj bazi podataka Connotea (Heckner, Mühlbacher i Wolf, 2008) te istraživanje korisničkih oznaka u hrvatskom *web* prostoru (Špiranec i Ivanjko, 2012). Provedena je analiza funkcionalnih i lingvističkih svojstava najpopularnijih korisničkih oznaka kako su predstavljene u oblacima na prethodno razmatranim stranicama za društveno čitanje. Konceptualni model korišten u istraživanju preuzet je iz prvog rada te su se prvo analizirali „(...) lingvistički aspekti: (morfo-)sintaksa, pravopis i leksički aspekti korisničkih oznaka“ (Heckner, Mühlbacher i Wolf, 2008: 4) te su oznake svrstavane u definirane skupine i podskupine, ovisno o tome je li oznaka jedna riječ (pridjev, prilog, imenica, glagol, broj, akronim, ostale nepromijenjive riječi) ili sastavljena od više riječi (složenica i složeni izraz).



Slika 7. Model za lingvističku analizu korisničkih oznaka (prema Heckner, Mühlbacher i Wolf (2008)).

Na isti korpus korisničkih oznaka potom je primijenjen funkcionalan kategorijalni model koji „(...) razlikuje korisničke oznake vezane uz tematiku i one koje to nisu: tematske oznake mogu opisivati sam resurs pružajući informaciju o autoru, izvoru ili datumu izdavanja, ili mogu opisivati sadržaj izvora“ (Ibid.: 6). Oznake koje nisu tematske pokazuju se kao specifične za korisničko označivanje jer jasno pokazuju da ne teže nikakvoj objektivnosti: one služe kako bi pokazale stav ili emocije indeksera prema dokumentu, u kojem slučaju govorimo o afektivnim oznakama, ili, s druge strane, kako bi ukazale na određenu radnju ili vremenski odnos korisnika prema izvoru – tada govorimo o oznakama vezanima uz vrijeme ili zadatak. Potonja skupina prepoznata je u prethodnim istraživanjima te je utvrđeno kako je riječ o „(...) oznakama poput oznaka 'to_do' ili 'to_read' koje su osobne i posve razumljive samo osobama koje ih dodjeljuju, a opisuju budući postupak“ (Špiranec i Ivanjko, 2012: 64). Ovdje treba napomenuti da se na stranicama za društveno čitanje često javljaju i osobne oznake koje su vezane za radnju u sadašnjosti ili prošlosti kao npr. „read-in-2014“ ili „did-not-finish“ a koje po svojoj funkciji spadaju u ovu skupinu korisničkih oznaka.



Slika 8. Model za funkcionalnu analizu korisničkih oznaka.

Uzorak korišten za analizu sastojao se od najpopularnijih korisničkih oznaka očitanih iz oblaka oznaka na prethodno predstavljenim stranicama za društveno čitanje. Nevelik broj stranica u pitanju predstavljao je prvo ograničenje ovoga istraživanja, a dodatna ograničenja pojavila su se uslijed različitog tretiranja i valoriziranja korisničkih oznaka na pojedinim stranicama. Naime, dvije stranice uopće nemaju mogućnost označivanja korisničkim oznakama (Riffle i Bookstr), stranica BookBrowse nudi oblak oznaka koji je evidentno moderiran i razlomljen prema različitim kriterijima: pokazuju se ili žanrovske, ili vremenske, ili mjesne, ili tematske korisničke oznake te samim time nije adekvatan za analizu prema gore navedenom modelu. Anobii, Libib i Booklikes podržavaju opciju korisničkog označivanja, no ne postoji mogućnost prikaza oblaka korisničkih oznaka formiranog na razini cijele stranice.¹⁶ Time se broj stranica na kojima su se analizirale korisničke oznake sveo na Goodreads sa 133 korisničkih oznaka te LibraryThing sa 74, odnosno ukupno 207 korisničkih oznaka sa dviju stranica za društveno čitanje. Slaba mogućnost da se rezultati poopće uz „(...) subjektivnu interpretaciju semantike oznaka autora istraživanja“ (Ibid.:66) pokazali su se stoga kao dva najproblematičnija aspekta i ovog istraživanja.

Lingvističkom analizom, baziranom na raščlanjivanju korisničkih oznaka prema vrstama riječi, pokazalo se da korisnici preferiraju označivati samo jednom riječi, te je na taj način označeno 74% od ukupnog broja analiziranih oznaka. Pri tom je znatan udio imenica: 70% na stranici LibraryThing, odnosno 39% na stranici Goodreads ili 50% sveukupno, dok su ostale


¹⁶ Poslan je upit na stranice Anobii, Libib i Booklikes s pitanjem je li moguće vidjeti oblak koji prikazuje cjelokupnost najpopularnijih oznaka na razini stranice. Odgovor je stigao jedino iz korisničke podrške Libiba koji interesantno podržava hipotezu ovog istraživanja: „Mnogi naši korisnici upotrebljavaju privatne informacije u njihovim oznakama, stoga ne prikazujemo *master* listu korisničkih oznaka“

vrste riječi u uporabi znatno rjeđe: slijedi postotak pridjeva upotrebljenih za označivanje: 22 oznake ili ukupno 11%.


Korištenje više riječi za označivanje na stranicama za društveno čitanje, relativno je učestalo te čini više od četvrtine analiziranog uzorka (53 oznake ili 26%), bilo da se radi o složenici ili složenom izrazu. Djelomično je razlog tome okolnost da se velik broj žanrovskih karakteristika ili opisnih kategorija iz svijeta književnosti sastoji od više riječi (*young adult*, *historical fiction* itd.) te da je, s druge strane, za stvaranje adekvatnih osobnih oznaka korisnika, pogotovo onih vezanih uz vrijeme i zadatak, često potrebno nekoliko riječi kako bi se postigla adekvatna razina izražajnosti („want-to-read“, „need-to-buy“, „did-not-finish“ itd.).

Udio pojedinih vrsta riječi na stranicama Goodreads i LibraryThing prikazani su grafički na slici 8 i 9.

Slika 9. Prikaz postotnih udjela analiziranih korisničkih oznaka prema lingvističkom modelu na stranici LibraryThing i stranici Goodreads.



Korisničke oznake: lingvistička analiza




Slika 10. Grafički prikaz korisničkih oznaka na stranicama za društveno čitanje ukupno, raščlanjenih prema lingvističkom modelu.

Korisničke su oznake pretežno birane iz engleskog jezika, izuzev tri oznake na arapskome jeziku pronađene na stranici Goodreads. Analizirane su i pogreške te varijante u


pisanju kojih je zabilježeno iznimno malo – 4 pogreške na stranici Goodreads – ukupno 3% - te dvije varijante u pisanju (1%), kao i neologizmi koji nisu evidentirani.

Budući da je polovica korisničkih oznaka imenica, može se zaključiti da znatan udio korisničkog označivanja počiva na karakteristikama poznatima iz uvriježene uporabe strukturiranih predmetnih jezika. Međutim polovica oznaka koje od toga odstupaju – bilo vrstom riječi, bilo složenošću izraza - ukazuje na specifične potrebe korisnika stranica za društveno čitanje da koriste i druge mogućnosti označivanja u svrhu organizacije i pretraživosti dokumenata. Na to ukazuju i rezultati funkcionalne analize korisničkih oznaka. Većinski udio u cjelokupnom analiziranom uzorku čine tematske korisničke oznake, sveukupno 68%, od kojih većina otpada na one vezane uz sadržaj (54%), a ostatak od 14% na oznake vezane uz resurs.



Slika 11. Korisničke oznake raščlanjene prema funkcionalnom modelu na stranicama LibraryThing i Goodreads, izražene u postotnim udjelima.

Slika 12. Grafički prikaz korisničkih oznaka ukupno, analiziranih prema funkcionalnom modelu.



Međutim, 10% korisničkih oznaka osobnog karaktera na stranici LibraryThing te njih čak 44% na stranici Goodreads, odnosno 32% sveukupno, ukazuju na povećanu sklonost korisnika stranica za društveno čitanje prema osobnim oznakama – oznakama koje bilo da izražavaju njihov stav ili emocije prema dokumentu koji se označuje (afektivne oznake), bilo onima koje služe da izraze realno odnošenje korisnika prema dokumentu u formi prošle, sadašnje ili buduće

radnje, što je značajno više u odnosu na rezultate dobivene u prethodnim istraživanjima: 6% u istraživanju Heckner, Mühlbacher i Wolf (2008.), odnosno 8% u istraživanju Špiranec i Ivanjko (2011.).

Prema dobivenim rezultatima lingvističke i funkcionalne analize, može se zaključiti da je većina korisničkih oznaka upotrijebljenih za označivanje na stranicama za društveno čitanje jedna riječ i to imenica iz engleskoga jezika te je većinski tematska i vezana uz sadržaj. Takvi rezultati sugeriraju da korisnici svjesno ili nesvjesno slijede načine označavanja kakvi se koriste za organizaciju znanja u institucionaliziranim i profesionalnim okruženjima. Međutim, zabilježen je značajan udio složenih izraza, pri čemu isti nerijetko pripadaju u kategoriju osobnih oznaka prema svojoj funkciji. Gotovo trećina korisničkih oznaka je afektivna ili vezana uz vrijeme i zadatak, što ide u prilog hipotezi postavljenoj na početku istraživanja. Relativno velik broj osobnih oznaka svakako je vezan uz kontekst: stranice za društveno čitanje u velikoj mjeri služe korisnicima za predstavljanje i organizaciju informacija za vlastitu upotrebu, za stvaranje vlastite virtualne privatne knjižnice.

Takav zaključak potvrđuje naslućenu karakteristiku stranica za društveno čitanje: unatoč njihovom inherentno socijalnom karakteru, u korisničkom označivanju snažna je ne samo subjektivnost u postupku, već i personalizacija u intonaciji korisničkih oznaka.

5. ZAKLJUČAK

Više od desetljeća postojanja i rastuće popularnosti korisničke sadržajne obrade koja uključuje aktivnosti korisničkog označivanja, recenziranja te ocjenjivanja potaknula je mnoga razmatranja i istraživanja o njihovim dobrim i lošim stranama, prednostima i manama, mogućnostima i ograničenjima. To su pitanja koja se tiču kako rješavanja problema označivanja nepregledne količine sadržaja na internetu, tako i eventualnog uvođenja novih pristupnica u već obrađene dokumente predstavljene u, primjerice, knjižničnim katalozima. Naime, predstavljanje i organizacija informacija u oba slučaja konstantno teže optimizaciji imajući u vidu krajnjeg korisnika i njegove stvarne i potencijalne informacijske potrebe. Kao dio rješenja tog problema pojavila se mogućnost da u Web 2.0 okruženju upravo korisnik sudjeluje u procesu označivanja, donedavno rezerviranog isključivo za informacijske stručnjake. Taj je pomak omogućio da se proces označivanja demokratizira, da postane višeglasan i pluriperspektivan, ali i subjektivan i osoban, što su demonstrirala brojna istraživanja korisničke sadržajne obrade, uključujući istraživanje lingvističkih i funkcionalnih svojstava korisničkih oznaka na stranicama za društveno čitanje koje je provedeno za potrebe ovoga rada. Demokratičnost i višeglasje svakako se mogu smatrati prednostima korisničke obrade koje odgovaraju duhu vremena, međutim visoka razina subjektivnosti i personalnosti pokazuju se kao nešto problematičniji aspekti istog procesa. Oznake koje bi po definiciji trebale otvarati dodatne puteve pristupa za druge korisnike, u ovom bi slučaju mogle biti nerazumljive ili beskorisne te zatvoriti dokument u označiteljske granice razumljive tek korisniku koji indeksira. Uz dodatnu problematiku koja je inherentna korisničkom označivanju čini se da se s pravom postavlja pitanje treba li korisnik posjedovati svojevrsnu „kompetenciju za korisničko označivanje“ (Peters, 2009: 195) kako bi korisničke oznake dodijeljene izvorima doista predstavljale dodanu vrijednost za informacijsku zajednicu, a isto vrijedi i za korisničko recenziranje i ocjenjivanje dokumenata na internetu.

Nerijetko se nalazi na uvjerenje stručnjaka da bi optimalan bio kombinirani ili hibridni pristup koji uzima i spaja najbolje od folksonomija i od drugih strukturiranih načina sadržajnog označivanja (usp. npr. Yi i Chan, 2009). To se može postići, primjerice, procesom „kultiviranja tagova“ (*tag gardening*) koji bi se djelomice mogao provesti automatski, djelomice uz suradnju korisnika (usp. Peters, 2008: 235). Kultiviranjem bi se trebali riješiti ključni problemi korisničke

obrade kao što su balastne oznake, *spamovi*, generičke popularne oznake niske informativnosti, neokupljeni sinonimi i nerazriješeni homonimi te nepostojanje semantičkih relacija uopće. Pitanje koje se s tim u vezi može postaviti jest koliko će takvi ili slični postupci izmijeniti, a koliko očuvati kvalitete i specifičnosti rječnika koji reflektiraju autentičan jezik i ponašanje stvarnih korisnika. Primjerice, korisničke oznake vezane uz vrijeme i zadatak (Isabella Peters zove ih performativnim oznakama) čija se relativno visoka učestalost na stranicama za društveno čitanje pokazala u istraživanju, mogu se učiniti presubjektivnima i preosobnima da bi opstale u kultiviranim folksonomijama, međutim činjenica je isto tako da „(...) bi one mogle biti posebno značajne za pronalaženje informacija. Performativne korisničke oznake predstavljaju indirektni vrijednosni sud o izvoru, s obzirom na to da ga mogu označiti kao vrijednog čitanja ('toread') ili ga preporučiti (@Peter)“. Isto se može reći i za ostale forme korisničke sadržajne obrade: iako profesionalne recenzije i ocjene mogu biti „kontrolirani vodič“ korisnicima prema dokumentima koje bi ih mogli zanimati, one koje generiraju sami korisnici nerijetko sadržavaju suvišak osobnog dojma i vrednovanja koji korisniku koji ih čita mogu značiti odlučujuć korak prema otkrivanju novih informacija i povezivanju s drugim korisnicima u virtualne zajednice na temelju zajedničkog interesa i preferencija. Stoga bi svako kultiviranje ili hibridizacija trebali uključivati opravdan oprez koji bi funkcionirao kao barem djelomična garancija očuvanja svih nabrojenih prednosti samoniklih korisničkih rječnika.

To svakako vrijedi u slučaju stranica za društveno čitanje koje svoj značaj i popularnost u suvremenom Web 2.0 okruženju neupitno duguju sinergiji ponovno otkrivene društvenosti čitanja te novootkrivene krajnje subjektivnosti korisničke sadržajne obrade.

BIBLIOGRAFIJA

Balby Marinho, Leandro ... et al. Recommender Systems for social tagging systems. New York: Springer, 2012.

Banek Zorica, Mihaela; Špiranec, Sonja; Zauder, Krešimir. Collaborative tagging : providing user created organizational structure for Web 2.0. // Zbornik radova 1. međunarodne znanstvene konferencije „The future of information sciences : INFuture 2007 : Digital information and heritage“. / uredili Sanja Seljan i Hrvoje Stančić. Zagreb : Filozofski fakultet, Odsjek za informacijske znanosti = Faculty of Humanities and Social Sciences, Department of Information Sciences, 2007., str. 193-202.

Bater, Jo; Rowley, Jennifer. Social reproduction and exclusion in subject indexing. // Journal of documentation 3, 67(2011), str. 431-448. Dostupno na: <http://dx.doi.org/10.1108/00220411111124532> (10.04.2017.).

Cavallo, Guglielmo; Chartier, Roger. A history of reading in the West, Amherst : University of Massachusetts Press, 1999.

Cordón-García, José-Antonio; Alonso-Arevalo, Luis; Gomez-Diaz, Raquel. Social reading : platforms, applications, clouds and tags. Philadelphia, PA : Chandos Pub., 2013.

Dionisio, Nicole. An unofficial guide to Goodreads for readers and writers. S.n.: MakeUseOf.com, 2014.

Heckner, Markus; Mühlbacher, Susanne; Wolff, Christian. Tagging tagging : analyzing user keywords in scientific bibliography management systems. // Journal of digital information 9, 2(2008), str. 1-19. Dostupno na: <http://journals.tdl.org/Jodi/article/view/246> (1.05.2017.).

Huang, Yun Kuei; Yan, Wen I. Dissemination motives and effects of internet book reviews. // The electronic library 6, 28(2010), str. 804-817. Dostupno na: <http://dx.doi.org/10.1108/02640471011093507> (19.04.2017.).

Huang, Yun Kuei; Yan, Wen I. Using networked narratives to understand internet book reviews in online communities. // The electronic library 1, 32(2014), str. 17-30. Dostupno na: <http://dx.doi.org/10.1108/EL-05-2012-0053> (19.04.2017.).

Naik, Yesha. Finding Good Reads on Goodreads : readers take RA into their own hands. // Reference & user service quarterly 4, 51(2012), str. 319-323. Dostupno na: <http://www.jstor.org/stable/refuseserq.51.4.319> (1.04.2017.).

Peters, Isabella. Folksonomies : indexing and retrieval in Web 2.0. Berlin : De Gruyter Saur, 2009.

Smith, Gene. Tagging : people-powered metadata for the social Web. Berkley : New Riders, 2008.

Svenonius, Elaine. Intelektualne osnove organizacije informacija. Lokve : Benja, 2005.

Špiranec, Sonja. Subjektivna paradigma sadržajnog označivanja. // Vjesnik bibliotekara hrvatske 57, 1/3(2014), str. 1-14.

Špiranec, Sonja; Ivanjko, Tomislav. Predmetni jezici s korisničkim jamstvom : što možemo naučiti od folksonomija : preliminarno istraživanje. // 15. seminar Arhivi, knjižnice, muzeji : mogućnosti suradnje u okruženju globalne informacijske strukture : zbornik radova / uredili Damir Hasenay i Maja Krtalić. Zagreb : Hrvatsko knjižničarsko društvo, 2012., str. 57-72.

Špiranec, Sonja; Ivanjko, Tomislav. Korisničko označivanje tekstnih i vizualnih informacija : što mogu očekivati AKM ustanove. // 16. seminar Arhivi, knjižnice, muzeji : mogućnost suradnje u

okruženju globalne informacijske infrastrukture : zbornik radova / uredile Nives Tomašević i Ivona Despot. Zagreb : Hrvatsko knjižničarsko društvo, 2013., str. 66-79.

Špiranec, Sonja; Livaja, Blaž. Korisničke oznake i predmetne odrednice : istraživanje funkcionalnosti kao prilog unapređenju predmetnoga pristupa. // Vjesnik bibliotekara Hrvatske 57, 1/3(2014), str. 51-68.

Tadić, Katica. Rad u knjižnici. Opatija : Naklada Benja, 1994.

The wisdom of crowds. 2017. // Wikipedia: the free encyclopedia. Dostupno na: https://en.wikipedia.org/wiki/The_Wisdom_of_Crowds (13.04.2017.).

Thomas, Marliese; Caudle, Dana M.; Scmitz, Cecilia M. To tag or not to tag? // Library Hi Tech 3, 27(2009), str. 411-423. Dostupno na: <http://dx.doi.org/10.1108/07378830910988540> (10.03.2017.).

Thomas, Marliese; Caudle, Dana M.; Scmitz, Cecilia M. Trashy tags : problematic tags in LibraryThing. // New library world 5/6, 111(2010), str. 223-235. Dostupno na: <http://dx.doi.org/10.1108/03074801011044098> (10.03.2017.).

Vander Wall, Thomas. Folksonomy coinage and definition. 2007. // Vanderwall.net. Dostupno na: <http://vanderwal.net/folksonomy.html> (5.03.2017.).

Voorbij, Henk. The value of LibraryThing tags for academic libraries. // Online information review 2, 36(2012), str. 196–217. Dostupno na: <http://dx.doi.org/10.1108/14684521211229039> (1.04.2017.).

Wu, Dan; Xu, Xiaomei; Yu, Wenting. Comparing collaborative annotations on books between libraries and social community sites : a case study. // The electronic library 2, 34(2016), str. 178 – 195. Dostupno na: <http://dx.doi.org/10.1108/EL-09-2014-0171> (25.04.2017.).

Yi, Kwan; Chan, Lois Mail. Linking folksonomy to Library of Congress subject headings: an exploratory study. // Journal of documentation 6, 65(2009), str. 872-900. Dostupno na: <http://dx.doi.org/10.1108/00220410910998906> (27.04.2016.).

Zuccala, Alesia A. ...et al. Altmetrics for the humanities : comparing Goodreads reader ratings with citations to history books. // Aslib journal of information management 2, 6(2015), str. 320-336. Dostupno na: <http://dx.doi.org/10.1108/AJIM-11-2014-0152> (23.04.2017.).

INTERNETSKE STRANICE

Anobii. Dostupno na: <http://www.anobii.com/> (2.05.2017.).

Bookbrowse. Dostupno na: <https://www.bookbrowse.com/> (3.05.2017.).

Goodreads. Dostupno na: <https://www.goodreads.com/> (2.05.2017.).

LibraryThing. Dostupno na: <https://www.librarything.com/home> (2.05.2017.).

Libib. Dostupno na: <https://www.libib.com/> (2.05.2017.).

Riffle. Dostupno na: <https://www.rifflebooks.com/> (2.05.2017.).

Bookstr. Dostupno na: <https://www.bookstr.com/> (3.05.2017.).